



Rancang Bangun Sistem Kontrol Cerdas Instalasi Pengolahan Air Limbah (IPAL) Berbasis Kecerdasan Buatan *Artificial Neural Network (ANN) Backpropagation*

Diki Kurniawan Prasetyo^{1*}, Nur Vidia Laksmi B², Widi Aribowo³, As'ad Shidqy Aziz⁴
^{1,2,3,4} Sarjana Terapan Teknik Listrik, Fakultas Vokasi, Universitas Negeri Surabaya, Kota Surabaya, Indonesia

Article Info

Article history:

Received Agustus 02, 2026

Revised Agustus 21, 2026

Accepted Agustus 22, 2026

Keywords:

Artificial Neural Network

Backpropagation

ESP32

koagulasi

Total Suspended Solids

ABSTRACT

Hospitals generate domestic wastewater that must be treated through a Wastewater Treatment Plant (WWTP) before discharge into the environment, particularly through a coagulation stage using alum to reduce turbidity and Total Suspended Solids (TSS). Existing automatic control systems are generally rule-based and prone to coagulant overdosing due to the non-linear nature of the coagulation process. This study aims to design an intelligent WWTP control system based on an Artificial Neural Network (ANN) with a Backpropagation learning algorithm to determine the optimal activation duration of an alum dosing pump based on pH and turbidity (NTU) sensor inputs. The research employed a Research and Development (R&D) method with a quantitative experimental approach. The ANN model was built using a Multi-Layer Perceptron (MLP) architecture with a 2-5-1 configuration and a sigmoid activation function, implemented on an ESP32 microcontroller integrated with Node-RED for real-time remote monitoring, and tested directly at the WWTP of IBI Mother and Child Hospital, Surabaya. The results show that the ANN Backpropagation model successfully determined the coagulant dosing duration with an overall regression correlation coefficient (R All) of 0.94795 and a Mean Absolute Error (MAE) of 0.203502 across 100 test data points, equivalent to a deviation of about 0.2 seconds. Furthermore, the conversion relationship between turbidity (NTU) and TSS was formulated through the linear regression equation $TSS = 0.384 \times NTU - 5.80$, with a coefficient of determination $R^2 \approx 0.94$. These findings demonstrate that the designed system operates accurately, efficiently, and adaptively in controlling the WWTP coagulation process while maintaining effluent water quality within regulatory standards.

This is an open access article under the [CC BY-SA](https://creativecommons.org/licenses/by-sa/4.0/) license.



Corresponding Author:

Diki Kurniawan Prasetyo

Universitas Negeri Surabaya, Kota Surabaya, Indonesia

Email: diki.22064@mhs.unesa.ac.id

1. PENDAHULUAN

Rumah sakit merupakan fasilitas pelayanan kesehatan yang di samping memberikan manfaat medis bagi masyarakat, juga menghasilkan limbah cair domestik (non-B3) dari aktivitas operasional harian yang berpotensi mencemari badan air, mengontaminasi air tanah, dan menyebarkan penyakit nosokomial jika dibuang langsung tanpa pengolahan [1]. Instalasi Pengolahan Air Limbah (IPAL) dirancang untuk memproses limbah tersebut agar aman saat dilepas ke lingkungan sesuai baku mutu [2], salah satunya melalui tahapan koagulasi menggunakan tawas untuk mengikat partikel koloid [3]. Parameter kunci keberhasilan proses ini adalah penurunan *Total Suspended Solids* (TSS) di bawah ambang batas regulasi lingkungan (< 30 mg/L) [3]. Namun, karena pengujian laboratorium gravimetri TSS memakan waktu lama, pembacaan sensor kekeruhan (*turbidity*) dalam satuan NTU dimanfaatkan sebagai indikator fisik yang berkorelasi linier dengan TSS untuk mendukung estimasi secara *real-time* [4].

Meskipun teknologi *Internet of Things* (IoT) mulai diadaptasi untuk pemantauan kualitas air limbah [5], [6], sistem kendali otomatisasi dosis bahan kimia yang ada saat ini umumnya masih mengandalkan logika *rule-based* (IF-THEN) atau sistem penakaran konvensional [7]. Padahal, karakteristik proses koagulasi bersifat non-linear dan sangat fluktuatif akibat dinamika beban pencemar limbah harian [8]. Ketiadaan kendali adaptif ini menimbulkan *research gap*, di mana sistem kendali kaku sering mengalami kesalahan penakaran, baik berupa kekurangan dosis (*underdosing*) yang membuat air tetap keruh maupun kelebihan dosis (*overdosing/overshoot*) yang memicu pemborosan tawas serta residu kimia berbahaya pada air olahan.

Untuk mengatasi permasalahan tersebut, penelitian ini menawarkan kebaruan (*novelty*) berupa penerapan sistem kontrol cerdas berbasis *Artificial Neural Network* (ANN) dengan algoritma pembelajaran *Backpropagation* yang ditanamkan secara *embedded* pada mikrokontroler ESP32 [9]. Algoritma *Backpropagation* dipilih karena keunggulannya dalam melakukan pembelajaran berulang untuk meminimalkan nilai kesalahan (*error*) komputasi pada data non-linear [10], [11]. Kebaruan sistem ini juga terletak pada penentuan variabel keluaran berupa *durasi operasional dosing pump* (menit) berdasarkan kombinasi masukan sensor pH dan kekeruhan secara simultan agar injeksi koagulan lebih presisi [12]. Sistem ini didukung integrasi kecerdasan buatan dan IoT [13] melalui *dashboard* Node-RED berbasis MQTT [14], serta dilengkapi konfigurasi sensor ganda (*dual-sensor*) pada zona inlet dan outlet dengan mekanisme sirkulasi balik (*feedback loop*) otomatis.

Berdasarkan rumusan masalah yang ada, tujuan dari penelitian ini adalah: (1) menerapkan model regresi ANN *Backpropagation* dengan topologi 2-5-1 berbasis rasio efisiensi neuron Kolmogorov [15] pada mikrokontroler ESP32 untuk menentukan durasi optimal *dosing pump* tawas berdasarkan sensor pH dan kekeruhan; (2) menganalisis tingkat presisi dan akurasi prediksi durasi pengaktifan koagulan melalui evaluasi nilai *Mean Absolute Error* (MAE) pada 100 data uji eksperimental; dan (3) menganalisis serta merumuskan karakteristik persamaan regresi konversi kekeruhan (NTU) ke nilai baku mutu TSS (mg/L) melalui pendekatan *virtual sensing* yang tervalidasi uji laboratorium. Penerapan sistem cerdas ini diharapkan mampu mengoptimalkan efisiensi operasional IPAL rumah sakit sekaligus menjaga kualitas luaran air limbah tetap memenuhi baku mutu lingkungan.


2. METODE

2.1 Jenis dan Pendekatan Penelitian

Penelitian ini menggunakan metode Research and Development (R&D) dengan pendekatan kuantitatif eksperimental. Pendekatan eksperimental diterapkan pada tahap pengembangan model ANN *Backpropagation*, di mana peneliti memanipulasi variabel terkontrol melalui simulasi beban pencemar (*spiking*) pada skala laboratorium untuk memperoleh data kuantitatif berupa nilai pH, kekeruhan, dan durasi koagulan yang presisi. Penelitian dilaksanakan di IPAL Rumah Sakit Ibu dan Anak IBI Surabaya.

2.2 Arsitektur Model ANN

Model regresi ANN dirancang dengan arsitektur Multi-Layer Perceptron (MLP) konfigurasi 2-5-1, yaitu 2 neuron input (pH dan kekeruhan), 5 neuron pada lapisan tersembunyi dengan fungsi aktivasi sigmoid, dan 1 neuron output berupa durasi operasi dosing pump (dalam satuan menit). Proses pelatihan menggunakan algoritma *Backpropagation* yang terdiri atas empat tahap: perambatan maju (*forward propagation*), perambatan mundur (*backward propagation*) menggunakan *delta rule*, pembaruan bobot, dan evaluasi *Mean Absolute Error* (MAE). Karena parameter input memiliki satuan dan rentang berbeda (pH 0-14; kekeruhan 0-3000 NTU), data dinormalisasi ke rentang [0,1] menggunakan metode Min-Max Normalization sebelum pelatihan, dan output ANN yang berupa nilai desimal 0-1 didenormalisasi kembali menjadi satuan waktu (menit) untuk mengendalikan durasi aktivasi dosing pump.



Gambar 1 arsitektur ANN Backpropagation

2.3 Perangkat Keras dan Perangkat Lunak

Sistem diimplementasikan menggunakan mikrokontroler ESP32 sebagai unit pemroses utama yang menjalankan hasil pelatihan ANN (bobot dan bias) secara offline hasil pelatihan pada MATLAB. Perangkat input terdiri atas sensor pH-4502C dan sensor kekeruhan DFRobot Gravity Analog Turbidity Sensor yang dipasang pada dua titik: inlet bak Separator Biofilter (sebagai input ANN) dan bak penampungan akhir/Indicator Tank (sebagai validasi Quality Control), dilengkapi Float Level Switch sebagai proteksi level air. Perangkat output meliputi modul relay untuk mengendalikan dosing pump serta dua lampu indikator (hijau/merah) yang menunjukkan status kelayakan air. Data ditampilkan secara lokal melalui LCD I2C 16x2 dan ditransmisikan melalui protokol MQTT (HiveMQ Cloud) ke dashboard Node-RED untuk pemantauan jarak jauh dan pencatatan data secara real-time.


2.4 Prosedur Pengambilan dan Pengolahan Data

Data latih (training dataset) dikumpulkan secara eksperimental langsung dari fluktuasi air limbah aktual pada IPAL Rumah Sakit selama estimasi 14 hari kerja hingga diperoleh 100 titik data, tanpa manipulasi atau pencampuran buatan, agar model mampu mengenali pola non-linear sesuai kondisi riil operasional. Proses pelatihan model ANN dilakukan secara offline di MATLAB menggunakan fungsi pelatihan `traindx` dengan pembagian data 70% data latih, 15% data validasi, dan 15% data uji. Evaluasi performa model dilakukan melalui perhitungan koefisien korelasi regresi (R) pada tahap training, validation, testing, dan keseluruhan (R All), serta nilai Mean Absolute Error (MAE). Selain itu, dilakukan validasi hubungan konversi nilai kekeruhan (NTU) terhadap TSS menggunakan metode kalibrasi 5 titik dengan uji laboratorium sebagai pembanding, untuk memperoleh persamaan regresi linear $TSS = a \times NTU + b$.

2.5 Flowchart Prinsip Kerja Sistem

Prinsip kerja sistem diawali dengan inisialisasi pin serta pemeriksaan status *float level switch* pada bak ekualisasi (batas aman $\geq 60 \text{ cm}$) sebagai proteksi *dry-run* agar pompa tidak menyala dalam kondisi bak kosong. Ketika level air terpenuhi, ESP32 melakukan *snapshot* pembacaan parameter awal dari sensor pH 1 dan kekeruhan 1 pada air limbah mentah sebelum masuk ke bak pengolahan. Data masukan tersebut kemudian diproses menggunakan algoritma ANN *Backpropagation* (topologi 2-5-1) di dalam ESP32 untuk mengkalkulasi durasi optimal nyala *dosing pump* koagulan. Nilai durasi yang dihasilkan ditampilkan pada layar LCD 16x2 bersamaan dengan pengaktifan modul *relay* untuk mengoperasikan *dosing pump*, yang akan mati secara otomatis setelah waktu hitung mundur (*timer*) berakhir.

Tahap selanjutnya adalah validasi mutu akhir (*Quality Control*) pada bak penampungan akhir menggunakan pembacaan sensor pH 2 dan kekeruhan 2. Apabila kualitas air telah memenuhi standar baku mutu (pH 6–7 dan kekeruhan < 1200 NTU), sistem mengaktifkan LED hijau yang menandakan air aman dan siap dibuang ke saluran pembuangan luar. Sebaliknya, jika salah satu parameter berada di luar ambang batas aman, sistem mengaktifkan LED merah dan memicu mekanisme *feedback loop* dengan membuka jalur sirkulasi air kembali ke bak ekualisasi untuk diproses dan dihitung ulang dosis koagulannya dari awal.



Gambar 2 Flowchart prinsip kerja sistem

3. HASIL DAN PEMBAHASAN

3.1. Implementasi Perangkat keras dan Antarmuka Monitoring

Sistem kontrol IPAL diimplementasikan dalam sebuah box panel tertutup yang melindungi komponen elektronik dari sengatan listrik, debu, dan kelembapan. Mikrokontroler ESP32 berperan sebagai pengendali utama yang menjalankan algoritma ANN Backpropagation dan mengendalikan modul relay untuk mengaktifkan dosing pump koagulan secara otomatis. Panel dilengkapi LCD 16x2 I2C sebagai media informasi bagi petugas lapangan serta dua pilot lamp yang mengindikasikan status air olahan (merah = belum memenuhi standar, hijau = siap dibuang). Seluruh hasil pembacaan sensor ditransmisikan secara nirkabel melalui broker MQTT menuju dashboard Node-RED yang menampilkan nilai pH dan NTU dari dua titik pengukuran dalam bentuk gauge, grafik tren durasi operasional pompa, serta status sistem secara ringkas, sehingga memudahkan pemantauan kualitas air limbah secara real-time dari jarak jauh.



Gambar 3 perancangan Alat

3.2. Kalibrasi Sensor

Kalibrasi sensor kekeruhan dilakukan menggunakan larutan standar turbidity yang diencerkan secara bertingkat, sedangkan kalibrasi sensor pH menggunakan tiga larutan buffer standar (pH 4,00; 6,86; dan 9,18). Hasil pengujian menunjukkan tingkat error yang sangat kecil pada kedua sensor, sebagaimana disajikan pada Tabel 1 dan Tabel 2.

Tabel 1. Hasil Kalibrasi Sensor Kekeruhan

Cairan Kalibrasi	Tegangan (V)	Pembacaan Sensor (NTU)	Error (%)
1000 NTU	2,813	998,4	0,0016
Aquades murni	3,3	0	0

Tabel 2. Hasil Kalibrasi Sensor pH

Larutan Buffer	Tegangan (V)	Pembacaan Sensor	Error (%)
pH 4,00	3,29	4,00	0
pH 6,86	2,53	6,86	0
pH 9,18	2,07	9,14	0,04

3.3 Performa Model ANN Backpropagation

Model ANN dilatih menggunakan 100 data eksperimental hasil pembacaan sensor pH dan kekeruhan beserta target waktu pengendapan tawas. Hasil pelatihan menunjukkan performa regresi yang sangat baik pada seluruh tahapan, sebagaimana dirangkum pada Tabel 3.

Tabel 3. Nilai Koefisien Korelasi Regresi (R) Model ANN

Tahap	Nilai R	Persamaan Garis
Training	0,94419	$\text{Output} \approx 0,93 \times \text{Target} - 0,0041$
Validation	0,97626	$\text{Output} \approx 0,90 \times \text{Target} - 0,0067$
Testing	0,94555	$\text{Output} \approx 0,82 \times \text{Target} - 0,032$
All (Total)	0,94795	$\text{Output} \approx 0,91 \times \text{Target} - 0,0086$

Nilai R Training sebesar 0,94419 membuktikan bahwa arsitektur jaringan 2-5-1 mampu mengenali karakteristik non-linearitas fluktuasi pH dan kekeruhan pada data primer IPAL. Nilai R Validation yang tertinggi (0,97626) menunjukkan bahwa model tetap stabil dan tidak mengalami overfitting selama proses

iterasi. Nilai R Testing yang konsisten di atas 0,94 mengonfirmasi bahwa model tetap presisi ketika dihadapkan pada data baru di luar data latih. Secara akumulatif, nilai R All sebesar 0,94795 menegaskan bahwa model ANN Backpropagation memiliki kemampuan generalisasi yang tinggi terhadap variasi karakteristik air limbah.

Evaluasi akurasi prediksi melalui perhitungan Mean Absolute Error (MAE) pada 100 data uji menghasilkan nilai MAE sebesar 0,203502. Nilai ini menunjukkan bahwa rata-rata margin kesalahan durasi penyuntikan tawas oleh ESP32 hanya berkisar 0,2 detik, yang secara langsung berkorelasi dengan nilai koefisien regresi total (R All) sebesar 0,94795. Dengan demikian, implementasi rumus non-linear ANN pada memori internal ESP32 terbukti andal untuk diterapkan pada sistem otomatisasi dosing pump, sekaligus efektif mencegah pemborosan bahan kimia (over-dosing) akibat penakaran manual yang tidak presisi.

3.4 Validasi Konversi Kekeruhan (NTU) terhadap TSS

Mengingat baku mutu lingkungan menggunakan parameter TSS (mg/L) sedangkan sistem berbasis sensor kekeruhan (NTU), dilakukan validasi konversi menggunakan metode kalibrasi 5 titik terhadap hasil uji laboratorium. Hasil regresi linear menghasilkan persamaan $TSS = 0,384 \times NTU - 5,80$ dengan koefisien determinasi $R^2 \approx 0,94$, yang menunjukkan hubungan linear yang kuat antara kedua parameter tersebut sehingga estimasi TSS dapat diperoleh secara real-time hanya dari pembacaan sensor kekeruhan tanpa perlu pengujian laboratorium yang memakan waktu.

3.5 Sistem Indikator dan Umpan Balik (Feedback Loop)

Sistem menetapkan rentang aman pada pH 6-7 dan kekeruhan di bawah 1200 NTU sebagai acuan klasifikasi kondisi air limbah. Apabila kedua parameter berada dalam rentang tersebut, ESP32 mengaktifkan indikator lampu hijau yang menandakan air layak dibuang; sebaliknya, apabila salah satu parameter berada di luar ambang batas, sistem mengaktifkan lampu merah dan memicu sirkulasi ulang air menuju bak equalisasi untuk diproses kembali oleh algoritma ANN. Mekanisme feedback loop ini memastikan bahwa air yang dibuang ke lingkungan telah melalui validasi ganda (dual quality control) sehingga konsisten memenuhi baku mutu yang berlaku.

4. KESIMPULAN

Berdasarkan hasil perancangan, pengujian, dan pembahasan, dapat disimpulkan bahwa: (1) model regresi Artificial Neural Network (ANN) Backpropagation dengan arsitektur 2-5-1 berhasil diterapkan untuk menentukan durasi aktivasi dosing pump koagulan secara otomatis berdasarkan input sensor pH dan kekeruhan, dengan nilai koefisien korelasi regresi total (R All) sebesar 0,94795 yang menunjukkan kemampuan model mengenali pola non-linear dengan sangat baik; (2) tingkat akurasi prediksi durasi pengaktifan koagulan tergolong sangat tinggi, ditunjukkan oleh nilai Mean Absolute Error (MAE) sebesar 0,203502 pada 100 data uji, setara deviasi durasi sekitar 0,2 detik, sehingga efektif mencegah pemborosan bahan kimia (over-dosing); dan (3) hubungan konversi antara nilai kekeruhan (NTU) dan Total Suspended Solids (TSS) berhasil dirumuskan melalui persamaan regresi linear $TSS = 0,384 \times NTU - 5,80$ dengan koefisien determinasi $R^2 \approx 0,94$, yang valid untuk mengestimasi TSS air limbah secara real-time. Untuk pengembangan lebih lanjut, disarankan penambahan jumlah dan variasi data latih, penerapan mekanisme retraining berkala, kalibrasi ulang persamaan konversi TSS pada karakteristik limbah lain, perluasan kendali otomatis ke aktuator IPAL lainnya, serta perbandingan performa ANN Backpropagation dengan metode kecerdasan buatan lain seperti fuzzy logic atau LSTM.

UCAPAN TERIMAKASIH

Penulis mengucapkan terimakasih kepada program studi sarjana terapan teknik listrik, universitas negeeri surabaya atas dukungan fasilitas dan sarana yang telah diberikan, dan terimakasih juga kepada semua pihak yang telah memberikan bantuan dan masukkan kepada penulis

REFERENSI

- [1] M. I. F. P. Alvin and R. P. Astutik, "Monitoring kolam IPAL dengan sistem IoT berbasis Wemos di RSI Nyai Ageng Pinatih," *Jurnal Teknik Elektro dan Informatika (E-Link)*, vol. 18, no. 1, pp. 87–96, 2023.
- [2] A. Wahyudi, "Mengenal lebih jauh tentang IPAL (Instalasi Pengolahan Air Limbah) komunal," *Media Lingkungan Hidup*, pp. 1–4, 2022.
- [3] G. A. Artha, "Penurunan nilai turbidity dan total suspended solids pada proses koagulasi," *Jurnal Rekayasa Lingkungan*, pp. 121–130, 2025.

- [4] V. A. Blessy and M. Kumar, "Predicting total suspended solids from turbidity for different types of soil particles," *Environmental Monitoring and Assessment*, pp. 30–39, 2023.
- [5] M. P. M. Putra, K. Gusri, D. Dzaudan, L. Jasa, and A. Wijaya, "Rancang bangun prototype monitoring instalasi pengolahan air limbah (IPAL) di Suwung berbasis Internet of Things," *Majalah Ilmiah Teknologi Elektro (MITE)*, vol. 24, no. 1, pp. 103–116, 2025.
- [6] I. S. Suasana, "Monitoring air limbah rumah sakit berdasarkan kadar pH dan suhu menggunakan Arduino," *Media Informasi Penelitian Kabupaten Semarang*, vol. 5, no. 1, pp. 166–179, 2023.
- [7] T. Wulandari, M. Rahmaniah, Erlangga, R. A. Munandar, Rizki, M. J. P. Perkasa, and R. Rachmat, "Rancang bangun sistem pengolahan air limbah ekstraksi berbasis Internet of Things di PT Sari Alam Sukabumi," *Karimah Tauhid*, vol. 3, no. 11, pp. 12779–12795, 2024.
- [8] A. A. Refaie, "Artificial neural network modeling approach for the prediction of five-day biological oxygen demand and wastewater treatment plant performance," *Journal of Cleaner Production*, pp. 1861–1877, 2021.
- [9] B. K. Ardiansyah, "Rancang bangun sistem pendeteksi kebakaran berbasis mikrokontroler ESP32," *Jurnal Teknik Elektro*, pp. 48–68, 2024.
- [10] G. I. Marthasari, S. A. Astiti, and Y. Azhar, "Prediksi data time-series menggunakan jaringan syaraf tiruan algoritma Backpropagation pada kasus prediksi permintaan beras," *Jurnal Pengembangan IT (JPIT)*, pp. 187–193, 2021.
- [11] R. Maiyuriska, "Penerapan jaringan syaraf tiruan dengan algoritma Backpropagation dalam memprediksi hasil panen gabah padi," *INFEB (Jurnal Informatika Ekonomi Bisnis)*, vol. 4, no. 1, pp. 28–33, 2022.
- [12] F. Nailah, D. I. Larasati, S. Siswanto, and A. Kalondeng, "Optimasi metode jaringan saraf tiruan Backpropagation untuk peramalan curah hujan bulanan di Kota Denpasar," *MATHunesa: Jurnal Ilmiah Matematika*, vol. 12, no. 1, pp. 134–140, 2024.
- [13] M. Zakiansyah, "Integrasi Internet of Things (IoT) dan kecerdasan buatan (AI) untuk smart city di Indonesia," *Jurnal Sains Student Research*, pp. 346–354, 2025.
- [14] M. A. Salam, "Monitoring dan Kendali Perangkat Berbasis Node-RED," *Jurnal Otomasi Industri*, pp. 14–19, 2024.
- [15] Damara, T. P. A., Mustaqim, A., Devyce, A., & Adawiyah, R. (2021). "JAYUS" Meja Payung Solar Cell. *Jurnal Teknik Elektro dan Komputer TRIAC*, 8(1), 23-25.
- [16] Z. Liu, Y. Wang, S. Vaidya, F. Ruehle, J. Halverson, M. Soljacic, T. Y. Hou, and M. Tegmark, "KAN: Kolmogorov-Arnold Networks," *arXiv preprint arXiv:2404.19756*, pp. 1–50, 2025.